(19)日本国特許庁（ＪＰ）　(12)**公開特許公報**（Ａ）　(11)特許出願公開番号
特開2001－318948
（P2001－318948A）
(43)公開日　平成13年11月16日(2001.11.16)

(51)Int.Cl.'	識別記号	Ｆ Ｉ	ﾃｰﾏｺｰﾄﾞ(参考)
Ｇ０６Ｆ　17/30	３５０	Ｇ０６Ｆ　17/30	３５０Ｃ　５Ｂ０７５
	１７０		１７０Ａ
	３４０		３４０Ｂ
	３８０		３８０Ｚ

審査請求　未請求　請求項の数13　ＯＬ　（全 18 頁）

(21)出願番号　特願2000－142232(P2000－142232)

(22)出願日　平成12年５月９日(2000.5.9)

(71)出願人　000005108
株式会社日立製作所
東京都千代田区神田駿河台四丁目６番地
(72)発明者　菅谷　奈津子
神奈川県川崎市幸区鹿島田890番地　株式会社日立製作所ビジネスソリューション開発本部内
(72)発明者　多田　勝己
神奈川県川崎市幸区鹿島田890番地　株式会社日立製作所ビジネスソリューション開発本部内
(74)代理人　100075096
弁理士　作田　康夫

最終頁に続く

(54)【発明の名称】　文書検索方法及び装置並びにその処理プログラムを記憶した媒体

(57)【要約】
【課題】文書や長い文章からなる条件で検索された文書を表示する場合でも、重要箇所の認識が容易な文書表示インターフェースを持つ文書検索システムを提供する。
【解決手段】登録時には、登録対象テキストから抽出した所定の文字列と出現情報を出現情報ファイルに格納し、所定の方法で算出した文字列の重みを重みファイルに格納する。検索時には、指定された検索条件から所定の文字列を抽出し、出現情報ファイルと重みファイルから取得した文字列の出現情報と重みを用いて検索条件とデータベース内テキストとの類似度を算出する。文書表示時には、検索に用いた文字列から重みの高い文字列を抽出し、表示対象テキストの中で抽出した文字列が含まれる部分の表示形式を変更し、テキストを表示する。
【効果】ユーザが表示文書の重要箇所を瞬時に認識でき、所望の文書か否かを高速に判別することが可能となる。

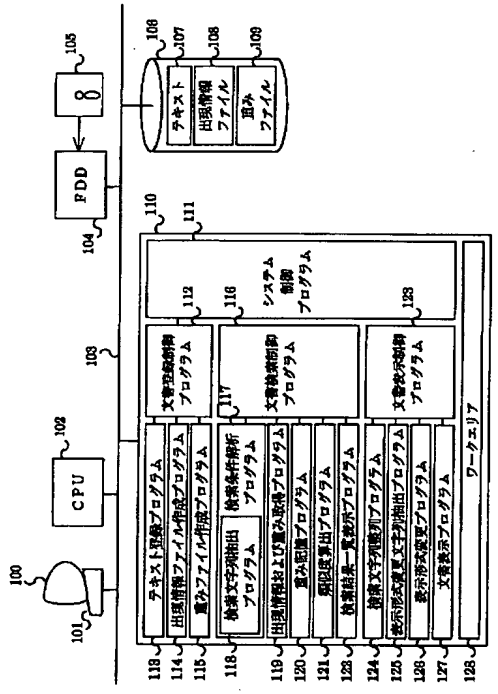

図1

【特許請求の範囲】

【請求項１】文書情報を文字コードデータとして蓄積したテキストデータベースを対象として、
検索条件の内容とテキストデータベース中のテキストの内容が類似する度合いを類似度として所定の方法で算出する文書検索方法において、
該類似度を算出する際に用いた情報の中で、重要な情報を選択し、該情報を表示するステップを有することを特徴とした文書検索方法。

【請求項２】文書情報を文字コードデータとして蓄積したテキストデータベースを対象として、
登録対象テキストデータから所定の部分文字列と該部分文字列の該登録対象テキストデータにおける出現情報を抽出し、出現情報ファイルとして記憶する文書登録ステップと、
検索条件から所定の部分文字列を抽出し、該出現情報ファイルから取得した該部分文字列の出現情報を用いて、検索条件の内容とテキストデータベース中のテキストの内容が類似する度合いを類似度として所定の方法で算出する文書検索ステップを有する文書検索方法において、
該部分文字列から重要な部分文字列を選択し、該類似度を算出する際に用いた情報の中で、該重要な部分文字列に関する情報を表示する重要情報表示ステップを有することを特徴とした文書検索方法。

【請求項３】請求項２記載の文書検索方法において、
前記重要情報表示ステップは、前記部分文字列の重要度を所定の方法で算出し、該重要度の降順に所定の数の部分文字列を抽出する高重要度部分文字列抽出ステップと、　該高重要度部分文字列抽出ステップで抽出した部分文字列に関する前記出現情報あるいは前記類似度の算出に寄与した度合いを表示する高重要度情報表示ステップを有し、
前記重要な部分文字列とは、該高重要度部分文字列抽出ステップで、該重要度の降順に所定の数だけ抽出した部分文字列であり、
前記重要な部分文字列に関する情報とは、該重要な部分文字列に関する該出現情報あるいは該類似度の算出に寄与した度合いを含むことを特徴とした文書検索方法。

【請求項４】請求項２記載の文書検索方法において、
前記文書検索ステップは、検索条件から所定の部分文字列を抽出し、情報を表示する部分文字列を該部分文字列の中からユーザに選択させる情報表示部分文字列選択ステップと、
前記出現情報ファイルから取得した該部分文字列の出現情報を用いて、検索条件の内容とテキストデータベース中のテキストの内容が類似する度合いを類似度として所定の方法で算出する類似度算出ステップを有し、
前記重要情報表示ステップは、該情報表示部分文字列選択ステップにおいて選択された部分文字列を取得する選択部分文字列取得ステップと、　該選択部分文字列取得

ステップで取得した部分文字列に関する前記出現情報あるいは前記類似度の算出に寄与した度合いを表示する選択情報表示ステップを有し、
前記重要な部分文字列とは、該情報表示部分文字列選択ステップにおいて、選択された部分文字列であり、
前記重要な部分文字列に関する情報とは、該重要な部分文字列に関する該出現情報あるいは該類似度の算出に寄与した度合いを含むことを特徴とした文書検索方法。

【請求項５】請求項２記載の文書検索方法において、
前記文書検索ステップは、検索条件から所定の部分文字列を抽出し、該部分文字列に対して部分文字列の追加あるいは削除をユーザに実施させる部分文字列編集ステップと、
該部分文字列編集ステップで編集された該部分文字列の出現情報を、前記出現情報ファイルから取得し、該出現情報を用いて、検索条件の内容とテキストデータベース中のテキストの内容が類似する度合いを類似度として所定の方法で算出する編集後類似度算出ステップを有し、
前記重要情報表示ステップは、該部分文字列編集ステップにおいて追加された部分文字列を取得する追加部分文字列取得ステップと、　該追加部分文字列取得ステップで取得した部分文字列に関する前記出現情報あるいは前記類似度の算出に寄与した度合いを表示する追加情報表示ステップを有し、
前記重要な部分文字列とは、該部分文字列編集ステップにおいて、追加された部分文字列であり、
前記重要な部分文字列に関する情報とは、該重要な部分文字列に関する該出現情報あるいは該類似度の算出に寄与した度合いを含むことを特徴とした文書検索方法。

【請求項６】請求項２記載の文書検索方法において、
前記重要情報表示ステップは、前記部分文字列から前記類似度の算出に寄与した順に所定の数の部分文字列を抽出する寄与部分文字列抽出ステップと、　該寄与部分文字列抽出ステップで抽出した部分文字列に関する前記出現情報あるいは該類似度の算出に寄与した度合いを表示する寄与情報表示ステップを有し、
前記重要な部分文字列とは、該寄与部分文字列抽出ステップで、該類似度の算出に寄与した順に所定の数だけ抽出した部分文字列であり、
前記重要な部分文字列に関する情報とは、該重要な部分文字列に関する該出現情報あるいは該類似度の算出に寄与した度合いを含むことを特徴とした文書検索方法。

【請求項７】文書情報を文字コードデータとして蓄積したテキストデータベースを対象として、
登録対象テキストデータから所定の部分文字列と該部分文字列の該登録対象テキストデータにおける出現情報を抽出し、出現情報ファイルとして記憶する文書登録ステップと、　検索条件から所定の部分文字列を抽出し、該出現情報ファイルから取得した該部分文字列の出現情報を用いて、検索条件の内容とテキストデータベース中の

テキストの内容が類似する度合いを類似度として所定の方法で算出する文書検索ステップと、
該文書検索ステップで該類似度を算出したテキストの中でユーザに指定されたテキストを表示する文書表示ステップを有する文書検索方法において、
該文書表示ステップは、該部分文字列から重要な部分文字列を選択し、該指定されたテキストの中で、該重要な部分文字列が含まれる部分の表示形式を変更する表示形式変更ステップを有することを特徴とした文書検索方法。

【請求項８】請求項７記載の文書検索方法において、
前記文書登録ステップは、前記登録対象テキストデータから所定の部分文字列と該部分文字列の該登録対象テキストデータにおける出現情報を抽出し、出現情報ファイルとして記憶する出現情報ファイル作成ステップと、
該部分文字列の重要度を所定の方法で算出し、重要度ファイルとして記憶する重要度ファイル作成ステップを有し、
前記文書表示ステップは、該部分文字列の重要度を該重要度ファイルから取得し、該取得した重要度の降順に所定の数の部分文字列を抽出する重要部分文字列抽出ステップと、
前記指定されたテキストの中で、該重要部分文字列抽出ステップで抽出した部分文字列が含まれる部分の表示形式を変更する重要部分文字列表示形式変更ステップを有し、
前記重要な部分文字列とは、該重要部分文字列抽出ステップで、該重要度の降順に所定の数だけ抽出した部分文字列であることを特徴とした文書検索方法。

【請求項９】請求項７記載の文書検索方法において、
前記文書検索ステップは、検索条件から所定の部分文字列を抽出し、表示形式を変更する部分文字列を該部分文字列の中からユーザに選択させる表示形式変更部分文字列選択ステップと、
前記出現情報ファイルから取得した該部分文字列の出現情報を用いて、検索条件の内容とテキストデータベース中のテキストの内容が類似する度合いを類似度として所定の方法で算出する類似度算出ステップを有し、
前記文書表示ステップは、該表示形式変更部分文字列選択ステップにおいて選択された部分文字列を取得する選択部分文字列取得ステップと、
前記指定されたテキストの中で、該選択部分文字列取得ステップで取得した部分文字列が含まれる部分の表示形式を変更する選択部分文字列表示形式変更ステップを有し、
前記重要な部分文字列とは、該表示形式変更部分文字列選択ステップにおいて選択された該表示形式を変更する部分文字列であることを特徴とした文書検索方法。

【請求項１０】請求項７記載の文書検索方法において、
前記文書検索ステップは、検索条件から所定の部分文字列を抽出し、該部分文字列に対しユーザに部分文字列の追加あるいは削除を実行させる部分文字列編集ステップと、
該部分文字列編集ステップで編集された該部分文字列の出現情報を、前記出現情報ファイルから取得し、該出現情報を用いて、検索条件の内容とテキストデータベース中のテキストの内容が類似する度合いを類似度として所定の方法で算出する編集後類似度算出ステップを有し、
前記文書表示ステップは、該部分文字列編集ステップにおいて追加された部分文字列を取得する追加部分文字列取得ステップと、
前記指定されたテキストの中で、該追加部分文字列取得ステップで取得した部分文字列が含まれる部分の表示形式を変更する追加部分文字列表示形式変更ステップを有し、
前記重要な部分文字列とは、該部分文字列編集ステップにおいて追加された該部分文字列であることを特徴とした文書検索方法。

【請求項１１】請求項７記載の文書検索方法において、
前記文書表示ステップは、前記部分文字列から前記類似度の算出に寄与した順に所定の数の部分文字列を抽出する寄与部分文字列抽出ステップと、　前記指定されたテキストの中で、該寄与部分文字列抽出ステップで抽出した部分文字列が含まれる部分の表示形式を変更する寄与部分文字列表示形式変更ステップを有し、
前記重要な部分文字列とは、該寄与部分文字列抽出ステップで、該類似度の算出に寄与した順に所定の数だけ抽出した部分文字列であることを特徴とした文書検索方法。

【請求項１２】文書情報を文字コードデータとして蓄積したテキストデータベースを対象として、
登録対象テキストデータから所定の部分文字列と該部分文字列の該登録対象テキストデータにおける出現情報を抽出し、出現情報ファイルとして記憶する文書登録手段と、
検索条件から所定の部分文字列を抽出し、該出現情報ファイルから取得した該部分文字列の出現情報を用いて、検索条件の内容とテキストデータベース中のテキストの内容が類似する度合いを類似度として所定の方法で算出する文書検索手段と、
該文書検索手段で該類似度を算出したテキストの中でユーザに指定されたテキストを表示する文書表示手段を備える文書検索装置において、
該文書表示手段は、該部分文字列から重要な部分文字列を選択し、該指定されたテキストの中で該重要な部分文字列が含まれる部分の表示形式を変更する表示形式変更手段を備えることを特徴とした文書検索装置。

【請求項１３】文書情報を文字コードデータとして蓄積したテキストデータベースを対象として、
登録対象テキストデータから所定の部分文字列と該部分

文字列の該登録対象テキストデータにおける出現情報を抽出し、出現情報ファイルとして記憶する文書登録モジュールと、
検索条件から所定の部分文字列を抽出し、該出現情報ファイルから取得した該部分文字列の出現情報を用いて、検索条件の内容とテキストデータベース中のテキストの内容が類似する度合いを類似度として所定の方法で算出する文書検索モジュールと、
該文書検索モジュールで該類似度を算出したテキストの中でユーザに指定されたテキストを表示する文書表示モジュールを含む文書検索システムを構築するためのプログラムを格納した記憶媒体において、
前記プログラムにおいて、該文書表示モジュールは、該部分文字列から重要な部分文字列を選択し、該指定されたテキストの中で該重要な部分文字列が含まれる部分の表示形式を変更する表示形式変更モジュールを含むことを特徴とした記憶媒体。

【発明の詳細な説明】

【０００１】

【発明の属する技術分野】本発明は、入力した条件に基づき登録文書を検索し、その検索した文書に関する情報を表示する文書検索技術に係る。

【０００２】

【従来の技術】近年、ワードプロセッサ等により作成される電子化文書が増大しており、今後も増大していくことが見込まれる。このため、文書検索の対象となるデータベースも大規模になってきている。その結果、文書検索によって得られる検索結果としての文書集合も大型化し、この中からユーザが本当に欲しい文書を探し出すことが困難になってきている。

【０００３】この問題を改善するため、従来よりランキング技術が提案されている。

【０００４】ランキング技術については、「Ranking Algorithms」（Donna Harman著、Information Retrieval、p.363-392）に具体的に記載されている。以下、これを従来技術１と呼ぶ。従来技術１は、ユーザが指定した検索条件（文章、文書、または複数の単語の列）の内容と類似する可能性を示す指標を算出する技術である。以下、その内容の一例を、図２を用いて説明する。

【０００５】検索は、簡単なベクトル演算によって実現される。このベクトルの要素は、データベース中に出現する全ての単語を重複排除したもの（但し、ストップワード等は除く）である。図２の例では、（factors, information, help, human, operation, retrieval, systems）が要素となっている。検索条件にその要素が存在すれば「１」を、存在しなければ「０」を該当位置に立てる。この結果、検索条件のベクトルＱ０が作成される。すなわち、「human factors in information retrieval systems」という検索条件に対し、（１，１，０，１，０，１，１）というベクトルＱ０が作成される。

【０００６】データベース中の文書に対しても同様に文書のベクトルが作成される。「factors」「information」「human」「retrieval」が含まれる文書１に対し、ベクトルＶ１（１，１，０，１，０，１，０）が作成される。また、「factors」「help」「human」「systems」が含まれる文書２に対し、ベクトルＶ２（１，０，１，１，０，０，１）が作成される。さらに、「factors」「operation」「systems」が含まれる文書３に対し、ベクトルＶ３（１，０，０，０，１，０，１）が作成される。

【０００７】ここで、ランキングに用いられる得点は、検索条件のベクトルＱ０と文書のベクトルＶｉ（ｉ＝１，２，３）とのベクトル積Ｖｉ・Ｑ０をとることによって算出される。その結果、文書１が４点、文書２が３点、文書３が２点となる。この得点はシステムが判断した検索条件との類似度であり、この得点が高い文書ほど検索条件の内容と類似する可能性が高いことを示している。

【０００８】なお、ベクトルの要素を「１」「０」ではなく、単語の重み（単語の出現頻度や文書データベース中の出現の偏り具合等で算出）等で表現することも可能である。例えば、「factors」の重み２、「information」の重み３、「human」の重み５、「retrieval」の重み３を用いて、文書１に対し、ベクトルＶ’１（２，３，０，５，０，３，０）が作成される。また同様に、「factors」の重み２、「help」の重み４、「human」の重み５、「systems」の重み１を用いて、文書２に対し、ベクトルＶ’２（２，０，４，５，０，０，１）が作成される。さらに、「factors」の重み２、「operation」の重み２、「systems」の重み１を用いて、文書３に対し、ベクトルＶ’３（２，０，０，０，２，０，１）が作成される。

【０００９】これらのベクトルＶ’ｉと検索条件式のベクトルＱ０とのベクトル積Ｖ’ｉ・Ｑ０をとることによって、各文書の得点が算出される。その結果、文書１が１３点、文書２が８点、文書３が３点となる。この得点は単語の重み、すなわち単語の重要度を考慮してシステムが判断した検索条件との類似度であり、この得点が高い文書ほど検索条件の内容と類似する可能性が高いことを示している。つまり、文書１が最も検索条件の内容と類似する可能性が高いとの結果を得る。

【００１０】この従来技術１では、検索条件の内容と類似する可能性を示す指標を算出しており、この指標に従って文書を閲覧することにより、大規模な文書データベースの中から所望の文書を高速に探し出すことできる可能性がある。しかし、得られた検索結果文書が本当に欲しい文書であるか否かは、実際に文書の内容をユーザが読んで判別しなければならない。このように、検索結果として得られた文書が所望の文書であるか否かを瞬時に判別することを支援するための技術として、文書のハイ

ライト表示技術がある。以下、これを従来技術２と呼ぶ。

【００１１】従来技術２は、検索結果として得られた文書の内容を表示する際に、ユーザが指定した検索条件中の文字列が含まれる部分を、他の文字列部分と異なる表示形式で表示する（以下、ハイライトと呼ぶ）というものである。ここでいう表示形式とは、例えば色、サイズ、フォントやスタイル（太字や斜体）等である。検索条件中の文字列が含まれる部分を他の文字列部分と異なる表示形式にすることにより、その単語が含まれる位置を瞬時に認識することができ、文書を先頭から読む場合よりも高速に所望の文書であるか否かを判別することが可能となる。

【００１２】

【発明が解決しようとする課題】従来技術１に示すランキング技術で用いられるベクトルの要素としては、単語が用いられることが多い。英語のように単語が分かち書きされている言語の場合には、ストップワード（in, theなど）以外の全ての単語が用いられる。日本語のように分かち書きされていない言語の場合には、文字種の異なるところで分割して得られる文字列や、ｎ文字（ｎは予め定められた1以上の整数）の連続する文字列、または辞書等を参照して抽出した単語等が用いられる。その結果、文書や長い文章を指定して検索を行い、その結果として得られた文書を従来技術２に示すハイライト表示技術で表示する際には、ハイライト対象となる文字列が多くなり、かえって重要な部分が見つけにくくなるという問題がある。

【００１３】以下、図３を用いて新聞記事データベースを例として説明する。本例では、検索条件としてサッカーのワールドカップの会場誘致に関する新聞記事文書を指定して検索を行っている。

【００１４】まず、検索条件として指定された文書「サッカーW杯試合会場、来月決定、選定の権限は協会に。日韓共催の二〇〇二年サッカーワールドカップ開催準備委員会は二十九日、開催地の候補である十五自治体の最高責任者らを集めて知事・市長会議を開いた。国際サッカー連盟（ＦＩＦＡ）が国内会場数を…」から検索に用いる文字列を抽出する。図３に示す例では、辞書等を参照して抽出した名詞、片仮名およびアルファベットを検索に用いる文字列として抽出している。この結果、検索条件から「サッカー、W杯、試合、会場、来月、決定、選定、権限、協会、日、韓、共催、ワールドカップ、開催、準備、委員会、地、候補、…」が抽出され、これらの文字列を用いて検索が行われる。その結果、検索条件の内容と類似する可能性を示す指標が算出され文書の一覧とともに出力される。そこで、検索条件の内容と類似する可能性が高い、すなわち最も得点の高い文書から閲覧し、本当に欲しい文書であるか否かをユーザが確認することになる。ここで、従来技術２のようなハイライト表示技術を利用すると、検索条件中の文字列が含まれる位置を瞬時に認識できるので、文書を先頭から読む場合よりも高速に所望の文書であるか否かを判別することができる。しかし、図３に示すように、文書や長い文章を指定して検索を行い、その結果として得られた文書を表示する際には、検索に用いる文字列が多いためにハイライト箇所（図３の例では、サイズを大きくし、斜体、強調を施している）が多くなり、かえって重要な部分が見つけにくくなってしまう。

【００１５】こうした問題に対し、本発明では、ユーザが所望とする文書か否かを容易に判別することが可能となる文書情報表示機能を実現することを目的とする。

【００１６】

【課題を解決するための手段】上記課題を改善するために、本発明では、以下の処理ステップを有する。

【００１７】すなわち、文書情報を文字コードデータとして蓄積したテキストデータベースを対象として、ユーザが指定した検索条件の内容とテキストデータベース中のテキストの内容が類似する度合いを類似度として所定の方法で算出する文書検索ステップと、文書検索ステップにおいて類似度を算出する際に用いた情報の中で、重要な情報を選択し、該情報を表示する文書表示ステップを有する。

【００１８】上記文書検索方法を用いた本発明の原理を、以下に説明する。文書の検索時にユーザから検索条件として文章や文書が指定された場合には、上述した文書検索ステップを実行し、ユーザが指定した検索条件の内容とテキストデータベース中のテキストの内容が類似する度合いを類似度として所定の方法で算出する。以下、文書検索ステップの処理内容の例を示す。まず、指定された検索条件（以下、検索条件文書と呼ぶ）から、予め定められた文字列を抽出する。この文字列としては、英語等の分かち書きされている言語であれば単語、そうでなければ文字種の異なるところで分割して得られる文字列や、ｎ文字（ｎは予め定められた１以上の整数）の連続する文字列、または辞書等を参照して抽出した単語等を用いる。検索条件文書として「サッカーW杯試合会場、来月決定、選定の権限は協会に。日韓共催の二〇〇二年サッカーワールドカップ開催準備委員会は二十九日、開催地の候補である十五自治体の最高責任者らを集めて知事・市長会議を開いた。国際サッカー連盟（ＦＩＦＡ）が国内会場数を…」が指定され、文字列として辞書等を参照して抽出した名詞、片仮名およびアルファベットを用いる場合には、図３に示すように、「サッカー、W杯、試合、会場、来月、決定、選定、権限、協会、日、韓、共催、ワールドカップ、開催、準備、委員会、地、候補、…」が抽出される。そして、これらの文字列のテキストデータベースにおける出現情報を抽出する。この出現情報としては、使用する検索方式により異なるが、文字列の出現する文書の番号や出現位置、出

現回数等を用いる。従来技術１の場合には、文書のベクトルを作成する際に必要となる文字列の出現文書番号や出現回数を用いる。さらに、この出現情報から所定の方法を用いて文字列の重みを算出する。この重みは、使用する検索方式によりその算出方法が異なるが、文字列の出現頻度や文書データベース中の出現の偏り具合等を用いて算出する。出現の偏り具合から算出される重みとして一般的に用いられているのは、「Ranking Algorithms」（Donna Harman著、Information Retrieval、p.363-392）にも記載されているIDF（Inverted Document Frequency）である。IDFは多くの文書に出現する文字列はストップワードである可能性が高く、重要度は低いという考え方から生み出された重みである。類似度はこの出現情報および重みを用いて、予め定められた算出方法で算出する。この算出方法は使用する検索方式により異なるが、例えば、図２に示す従来技術１で用いられている簡単なベクトル演算によっても算出できる。そして、算出した類似度を検索結果一覧として表示する。

【００１９】検索結果一覧上で選択した文書の表示要求がなされた場合には、上述した文書表示ステップを実行し、文書検索ステップにおいて類似度を算出する際に用いた情報の中で、重要な情報を選択し、該情報を表示する。以下、文書検索ステップの処理内容の例を示す。まず、文書検索ステップにおいて検索条件から抽出された文字列とその重みを、重みの降順に整列する。そして、整列した文字列の上位m個（mは予め定められた１以上の整数）を抽出する。このmの値はシステムで自動的に適切な値を設定しても良いし、ユーザに予め設定させておいても良い。また、文書表示毎に対話的にユーザに設定させ、適切な値を調整してもかまわない。図４に抽出した文字列の例を示す。本図に示す例では、mとして４を用いている。重みの降順に整列した文字列の上位４個を抽出することにより、「W杯」「サッカー」「ワールドカップ」「ＦＩＦＡ」が抽出される。次に、ユーザが表示対象として指定したテキスト（以下、表示文書と呼ぶ）の中で、抽出した文字列が含まれる部分の表示形式を変更し、表示文書を表示する。図４に示すように、抽出した「W杯」「サッカー」「ワールドカップ」「ＦＩＦＡ」が含まれる部分の表示形式（図４の例では、サイズを大きくし、斜体、強調を施している）を変更し、文書を表示する。こうすることにより、ユーザは文書中の重要箇所を一目で認識することができるようになる。本処理例において、上述した重要な情報とは重要な文字列に関するハイライト情報のことであり、重要な文字列とは重みの降順の上位m個（mは予め定められた１以上の整数）の文字列のことである。

【００２０】以上説明したように、本方式では、検索条件の内容と類似する可能性を示す指標に対して影響する文字列、例えば重みの高いものから順に予め決められた数の文字列を選定し、その文字列に関する情報として、例えばその文字列が含まれる部分だけ表示形式を変更して文書を表示する。こうすることにより、検索に用いられた文字列の中で重要な文字列に関する情報だけを表示することになるので、ユーザは文書中の重要箇所を瞬時に認識し、所望の文書か否かを高速に判別することができる。その結果、検索結果文書を閲覧する際のユーザインターフェースを向上することが可能となる。

【００２１】

【発明の実施の形態】以下、本発明の第一の実施例について図１を用いて説明する。

【００２２】本発明を適用した文書検索システムは、ディスプレイ１００、キーボード１０１、中央演算処理装置（ＣＰＵ）１０２、磁気ディスク装置１０６、フロッピディスクドライバ（ＦＤＤ）１０４、主記憶装置１１０およびこれらを結ぶバス１０３から構成される。磁気ディスク装置１０６は二次記憶装置の一つであり、テキスト１０７、出現情報ファイル１０８および重みファイル１０９が格納される。フロッピディスク１０５に格納されている情報は、ＦＤＤ１０４によりアクセスされる。

【００２３】主記憶装置１１０には、システム制御プログラム１１１、文書登録制御プログラム１１２、テキスト登録プログラム１１３、出現情報ファイル作成プログラム１１４、重みファイル作成プログラム１１５、文書検索制御プログラム１１６、検索条件解析プログラム１１７、出現情報および重み取得プログラム１１９、重み記憶プログラム１２０、類似度算出プログラム１２１、検索結果一覧表示プログラム１２２、文書表示制御プログラム１２３、検索文字列整列プログラム１２４、表示形式変更文字列抽出プログラム１２５、表示形式変更プログラム１２６および文書表示プログラム１２７が格納されるとともにワークエリア１２８が確保される。検索文字列抽出プログラム１１８は検索条件解析プログラム１１７に含まれる。以上のプログラムは磁気ディスク装置１０６、フロッピディスク１０５などのコンピュータで読み書きできる記憶媒体に格納することもできる。

【００２４】システム制御プログラム１１１はキーボード１０１からの指示を受け起動する。文書登録制御プログラム１１２はキーボード１０１からの文書登録指示により、システム制御プログラム１１１によって起動され、テキスト登録プログラム１１３、出現情報ファイル作成プログラム１１４および重みファイル作成プログラム１１５の制御を行う。文書検索制御プログラム１１６はキーボード１０１からの文書検索指示により、システム制御プログラム１１１によって起動され、検索条件解析プログラム１１７、出現情報および重み取得プログラム１１９、重み記憶プログラム１２０、類似度算出プログラム１２１および検索結果一覧表示プログラム１２２の制御を行う。文書表示制御プログラム１２３はキーボード１０１からの文書表示指示により、システム制御プ

ログラム１１１によって起動され、検索文字列整列プログラム１２４、表示形式変更文字列抽出プログラム１２５、表示形式変更プログラム１２６および文書表示プログラム１２７の制御を行う。

【００２５】以下、本実施例における処理内容の概要を説明する。

【００２６】文書を登録する際には、キーボード１０１からの文書登録指示により、システム制御プログラム１１１が文書登録制御プログラム１１２を起動し、文書登録制御プログラム１１２がテキスト登録プログラム１１３、出現情報ファイル作成プログラム１１４および重みファイル作成プログラム１１５による一連の文書登録処理を制御する。文書登録処理、すなわち文書登録制御プログラム１１２の処理内容を図５のＰＡＤ（Problem Analysis Diagram）図に示す。文書登録制御プログラム１１２は、図５に示すように、まずステップ６００で、テキスト登録プログラム１１３を起動し、ＦＤＤ１０４に挿入されたフロッピディスク１０５から登録する文書のテキストデータを読み込み、これをテキスト１０７として磁気ディスク装置１０６に格納する。テキストデータはフロッピディスク１０５を用いて入力するだけに限らず、通信回線やＣＤ－ＲＯＭ装置（図１には示していない）等を用いて他の装置から入力するような構成をとることも可能である。次にステップ６０１で、出現情報ファイル作成プログラム１１４を起動して、ステップ６００で読み込んだテキストデータから予め定められた文字列とその出現情報を抽出し、出現情報ファイル１０８として磁気ディスク装置１０６に格納する。ここで抽出する文字列としては、英語等の分かち書きされている言語であれば単語、そうでなければ文字種の異なるところで分割して得られる文字列や、ｎ文字（ｎは予め定められた１以上の整数）の連続する文字列、または辞書等を参照して抽出した単語等を用いる。また出現情報としては、使用する検索方式により異なるが、文字列の出現する文書の番号や出現位置、出現回数等、検索に必要な情報を用いる。従来技術１の場合には、文書のベクトルを作成する際に必要となる文字列の出現文書番号や出現回数を用いる。最後にステップ６０２で、重みファイル作成プログラム１１５を起動し、ステップ６０１で抽出した文字列の重みを、予め定められた算出方法を用いて算出し、重みファイル１０９として磁気ディスク装置１０６に格納する。この重みは、使用する検索方式によりその算出方法が異なるが、文字列の出現頻度や文書データベース中の出現の偏り具合（一般的には「Ranking Algorithms」（Donna Harman著、Information Retrieval、p.363-392）記載のIDFを用いる）等を用いて算出する。以上で文書登録処理は終了する。

【００２７】文書を検索する際には、キーボード１０１からの文書検索指示により、システム制御プログラム１１１が文書検索制御プログラム１１６を起動し、文書検索制御プログラム１１６が検索条件解析プログラム１１７、出現情報および重み取得プログラム１１９、重み記憶プログラム１２０、類似度算出プログラム１２１および検索結果一覧表示プログラム１２２による一連の文書検索処理を制御する。文書検索制御プログラム１１６は、まず文書検索の前準備として、磁気ディスク装置１０６に格納されている出現情報ファイル１０８と重みファイル１０９を主メモリ１１０に確保されたワークエリア１２８に読み込む。そして、文書検索処理では、図６のＰＡＤ図に示すように、まずステップ７００で、検索条件解析プログラム１１７を起動し、キーボード１０１から入力された検索条件を解析する。ここで、入力された検索条件には文章または文書が指定されていると、ステップ７０１で判断された場合には、ステップ７０２で検索文字列抽出プログラム１１８を用いて、検索条件として指定された文章または文書から、予め定められた文字列を抽出する。この文字列としては、文書登録制御プログラム１１２による文書登録処理での文字列抽出と同様に、英語等の分かち書きされている言語であれば単語、そうでなければ文字種の異なるところで分割して得られる文字列や、ｎ文字（ｎは予め定められた１以上の整数）の連続する文字列、または辞書等を参照して抽出した単語等を用いる。また、入力された検索条件には複数の単語の列が指定されていると、ステップ７０１で判断された場合には、ステップ７０３で検索条件から単語の列を抽出する。次にステップ７０４で、出現情報および重み取得プログラム１１９を起動し、検索条件から抽出した文字列（あるいは単語）の出現情報および重みを、ワークエリア１２８に読み込んだ出現情報ファイル１０８と重みファイル１０９から取得する。この文字列と重みは、ステップ７０５で重み記憶プログラム１２０を起動し、ワークエリア１２８に記憶しておく。次にステップ７０６で、類似度算出プログラム１２１を起動し、ステップ７０４で取得した文字列の出現情報と重みを用いて、予め定められた算出方法で検索条件とテキストデータ間の類似度を算出する。この算出方法は使用する検索方式により異なるが、例えば、従来技術１で用いられている簡単なベクトル演算によっても算出できる。最後にステップ７０７で、検索結果一覧表示プログラム１２２を起動し、ステップ７０６で算出した類似度の降順にテキストデータを整列し、検索結果一覧として表示する。以上で文書検索処理は終了する。

【００２８】文書を表示する際には、キーボード１０１からの文書表示指示により、システム制御プログラム１１１が文書表示制御プログラム１２３を起動し、文書表示制御プログラム１２３が検索文字列整列プログラム１２４、表示形式変更文字列抽出プログラム１２５、表示形式変更プログラム１２６および文書表示プログラム１２７による一連の文書表示処理を制御する。文書表示処理の処理内容を図７のＰＡＤ図に示す。文書表示制御プ

ログラム１２３は、図７に示すように、まずステップ８００で、検索文字列整列プログラム１２４を起動し、文書検索制御プログラム１１６による文書検索処理でワークエリア１２８に記憶した文字列とその重みを、重みの降順に整列する。次にステップ８０１で、表示形式変更文字列抽出プログラム１２５を起動し、ステップ８００で整列した文字列の上位m個（mは予め定められた１以上の整数）を抽出する。このmの値はシステムで自動的に適切な値を設定しても良いし、ユーザに予め設定させておいても良い。また、文書表示毎に対話的にユーザに設定させ、適切な値を調整してもかまわない。次にステップ８０２で、表示形式変更プログラム１２６を起動し、表示対象として指定された文書（以下、表示文書と呼ぶ）の中で、ステップ８０１で抽出した文字列が含まれる部分の表示形式を変更する。この表示形式の変更方法は従来技術２と同様である。最後にステップ８０３で、文書表示プログラム１２７を起動し、ステップ８０２で表示形式を変更した表示文書を表示して文書表示処理を終了する。

【００２９】以上が本実施例における処理内容の概要である。

【００３０】以下、本実施例の処理内容を具体例を用いて詳細に説明する。

【００３１】文書登録制御プログラム１１２による文書登録処理の内容は図５に示す通りである。以下、具体的に説明する。まずステップ６００で、テキスト登録プログラム１１３を起動し、ＦＤＤ１０４に挿入されたフロッピディスク１０５から登録する文書のテキストデータを読み込み、これをテキスト１０７として磁気ディスク装置１０６に格納する。次にステップ６０１で、出現情報ファイル作成プログラム１１４を起動して、ステップ６００で読み込んだテキストデータから予め定められた文字列を抽出する。ここで抽出する文字列としては、英語等の分かち書きされている言語であれば単語、そうでなければ文字種の異なるところで分割して得られる文字列や、ｎ文字（ｎは予め定められた１以上の整数）の連続する文字列、または辞書等を参照して抽出した単語等を用いる。さらに、抽出した文字列の出現情報を抽出し、出現情報ファイル１０８として磁気ディスク装置１０６に格納する。この出現情報としては、使用する検索方式により異なるが、文字列の出現する文書の番号や出現位置、出現回数等、検索に必要な情報を用いる。従来技術１の場合には、文書のベクトルを作成する際に必要となる文字列の出現文書番号や出現回数を用いる。図８に出現情報ファイル１０８の作成例を示す。本図に示す出現情報ファイル１０８には、辞書等を参照して抽出した単語が出現する文書の番号ならびにその文書における出現回数が格納されている。例えば、“W杯”という文字列は文書番号“１”の文書に“２”回出現しているので、その文書番号“１”ならびに出現回数“２”を出現情報ファイルに格納する。最後にステップ６０２で、重みファイル作成プログラム１１５を起動し、ステップ６０１で抽出した文字列の重みを、予め定められた算出方法を用いて算出し、重みファイル１０９として磁気ディスク装置１０６に格納する。この重みは、使用する検索方式によりその算出方法が異なるが、文字列の出現頻度や文書データベース中の出現の偏り具合等を用いて算出する。出現の偏り具合から算出される重みとして一般的に用いられているのは、「Ranking Algorithms」（Donna Harman著、Information Retrieval、p.363-392）にも記載されているIDF（Inverse Document Frequency）である。IDFは多くの文書に出現する文字列はストップワードである可能性が高く、重要度は低いという考え方から生み出された重みである。図８に示す重みファイル１０９には出現偏り具合を用いて算出した重みが格納されており、特定の文書にしか出現しない文字列“サッカー”の重みは高く、多くの文書に出現するストップワードに近い文字列“来月”の重みは小さくなる。以上で文書登録処理は終了する。

【００３２】文書検索制御プログラム１１６による文書検索処理の内容は図６に示す通りである。以下、具体的に説明する。まずステップ７００で、検索条件解析プログラム１１７を起動し、キーボード１０１から入力された検索条件を解析する。ここで、入力された検索条件には文章または文書が指定されていると、ステップ７０１で判断された場合には、ステップ７０２で検索文字列抽出プログラム１１８を用いて、検索条件として指定された文章または文書から、予め定められた文字列を抽出する。この文字列としては、文書登録制御プログラム１１２による文書登録処理での文字列抽出と同様に、英語等の分かち書きされている言語であれば単語、そうでなければ文字種の異なるところで分割して得られる文字列や、ｎ文字（ｎは予め定められた１以上の整数）の連続する文字列、または辞書等を参照して抽出した単語等を用いる。例えば、検索条件として「サッカーW杯試合会場、来月決定、選定の権限は協会に。日韓共催の二〇〇二年サッカーワールドカップ開催準備委員会は二十九日、開催地の候補である十五自治体の最高責任者らを集めて知事・市長会議を開いた。国際サッカー連盟（ＦＩＦＡ）が国内会場数を…」が指定された場合の例を図３に示す。図３に示す例では、辞書等を参照して抽出した名詞、片仮名およびアルファベットを検索に用いる文字列として抽出している。この結果、検索条件から「サッカー、W杯、試合、会場、来月、決定、選定、権限、協会、日、韓、共催、ワールドカップ、開催、準備、委員会、地、候補、…」が抽出される。また、入力された検索条件には複数の単語の列が指定されていると、ステップ７０１で判断された場合には、ステップ７０３で検索条件から単語の列を抽出する。ここで、検索条件として、例えば、「“サッカー”［ＡＮＤ］“ワールドカッ

プ”」のように、「“サッカー”と“ワールドカップ”の両方の文字列が現れる文書を探せ」というような複数の単語の論理条件が指定された場合には、単語の列として“サッカー”と“ワールドカップ”を抽出する。次にステップ７０４で、出現情報および重み取得プログラム１１９を起動し、検索条件から抽出した文字列（あるいは単語）の出現情報および重みを、ワークエリア１２８に読み込んだ出現情報ファイル１０８と重みファイル１０９から取得する。例えば“サッカー”という文字列の出現情報と重みを、図８に示す出現情報ファイル１０８と重みファイル１０９から取得すると、文書番号“１”に“３”回出現するという出現情報と、“８０”という重みが得られる。この文字列と重み、例えば“サッカー”の重み“８０”は、ステップ７０５で重み記憶プログラム１２０を起動し、ワークエリア１２８に記憶しておく。次にステップ７０６で、類似度算出プログラム１２１を起動し、ステップ７０４で取得した文字列の出現情報と重みを用いて、予め定められた算出方法で検索条件とテキストデータ間の類似度を算出する。この算出方法は使用する検索方式により異なるが、例えば、従来技術１で用いられている簡単なベクトル演算によっても算出できる。最後にステップ７０７で、検索結果一覧表示プログラム１２２を起動し、ステップ７０６で算出した類似度の降順にテキストデータを整列し、図３に示すような検索結果一覧として表示する。この結果、文書番号“１２３”の文書が、指定された検索条件の内容と最も類似する可能性の高い文書であることが分かる。以上で文書検索処理は終了する。

【００３３】文書表示制御プログラム１２３による文書表示処理の内容は図７に示す通りである。以下、具体的に説明する。まずステップ８００で、検索文字列整列プログラム１２４を起動し、文書検索制御プログラム１１６による文書検索処理でワークエリア１２８に記憶した文字列とその重みを、重みの降順に整列する。この整列処理の処理内容を図４に示す。整列処理を行うことにより、文字列が重みの降順、すなわち、重み“８０”の“W杯”、“サッカー”、重み“７０”の“ワールドカップ”、重み“６０”の“ＦＩＦＡ”、重み“５０”の“会場”、…の順に並べられる。次にステップ８０１で、表示形式変更文字列抽出プログラム１２５を起動し、ステップ８００で整列した文字列の上位m個（mは予め定められた１以上の整数）を抽出する。このmの値はシステムで自動的に適切な値を設定しても良いし、ユーザに予め設定させておいても良い。また、文書表示毎に対話的にユーザに設定させ、適切な値を調整してもかまわない。図４に示す例では、上位４個、すなわちmの値を４としている。その結果、表示形式を変更する文字列として“W杯”、“サッカー”、“ワールドカップ”および“ＦＩＦＡ”が抽出される。そしてステップ８０２で、表示形式変更プログラム１２６を起動し、表示対象として指定された文書（以下、表示文書と呼ぶ）の中で、ステップ８０１で抽出した文字列が含まれる部分の表示形式を変更する。この表示形式の変更方法は従来技術２と同様である。最後にステップ８０３で、文書表示プログラム１２７を起動し、ステップ８０２で表示形式を変更した表示文書を表示する。図４に文書番号“１２３”、文書番号“００３”の文書表示例を示す。本図に示す例では、表示形式を変更する文字列“W杯”、“サッカー”、“ワールドカップ”および“ＦＩＦＡ”が含まれる部分のサイズが大きく、斜体、強調が施されて表示されている。以上で、文書表示処理を終了する。

【００３４】以上説明したように、本実施例では、検索に用いられた文字列の中から、重要な文字列を選定し、その文字列が含まれる部分の表示形式のみを変更している。文書や長い文章を指定して検索を行い、その結果として得られた文書を表示する際に、検索に用いた文字列全ての表示形式を変更すると、図３に示すように変更箇所が多くなり、かえって重要な部分が見つけにくくなるという問題があるが、本実施例に示す方法を用いることにより、重要度の高い箇所に限定し、表示形式を変更することができる。

【００３５】このことにより、ユーザは文書中の重要箇所を瞬時に認識し、所望の文書か否かを高速に判別することが可能となる。その結果、検索結果文書を閲覧する際のユーザインターフェースを向上することができる。

【００３６】本実施例では、重みの高い文字列の表示形式を変更する場合の例について説明したが、表示形式を変えるだけではなく、重みの高い文字列に関する情報、例えば出現頻度等を一覧として表示することも上記と同様の処理で実現することが可能である。

【００３７】また本実施例では、文字列を同一の表示形式に変更する場合の例について説明したが、文字列の重みの値に応じて、表示形式を変えることも上記と同様の処理で実現可能である。例えば、最も重みの高い文字列に対してはサイズを大きく、目立つ色に変更する。次に重みの高い文字列に対してはサイズのみを大きくすることにより、どの文字列がどの程度重要であるかを瞬時に認識することができる。

【００３８】以下、本発明の第二の実施例について説明する。

【００３９】本実施例は、検索条件として指定された文章あるいは文書から抽出した検索用の文字列を編集する際に、文書表示時に表示形式を変更する（以下、ハイライトと呼ぶ）文字列をユーザに選択させる方法である。本実施例により、ユーザが重要視している文字列のみが文書表示時にハイライトされるので、ユーザは文書中の重要箇所を瞬時に認識し、所望の文書か否かを高速に判別することが可能となる。

【００４０】本実施例は基本的に第一の実施例（図１）と同様の構成をとるが、その中の文書検索制御プログラ

ム１１６および文書表示制御プログラム１２３が制御するプログラムの構成が異なる。文書検索制御プログラム１１６ａが制御するプログラムの構成を図９に、文書表示制御プログラム１２３ａが制御するプログラムの構成を図１０に示す。文書検索制御プログラム１１６ａはキーボード１０１からの文書検索指示により、システム制御プログラム１１１によって起動され、検索条件解析プログラム１１７、検索文字列編集プログラム９００、表示形式変更文字列選択プロクラム９０１、出現情報および重み取得プログラム１１９、類似度算出プログラム１２１および検索結果一覧表示プログラム１２２の制御を行う。文書表示制御プログラム１２３ａはキーボード１０１からの文書表示指示により、システム制御プログラム１１１によって起動され、表示形式変更文字列取得プログラム１０００、表示形式変更プログラム１２６および文書表示プログラム１２７の制御を行う。

【００４１】以下、第一の実施例と異なる文書検索制御プログラム１１６ａによる文書検索処理、文書表示制御プログラム１２３ａによる文書表示処理の処理内容について説明する。

【００４２】文書を検索する際には、キーボード１０１からの文書検索指示により、システム制御プログラム１１１が文書検索制御プログラム１１６ａを起動し、文書検索制御プログラム１１６ａが検索条件解析プログラム１１７、検索文字列編集プログラム９００、表示形式変更文字列選択プログラム９０１、出現情報および重み取得プログラム１１９、類似度算出プログラム１２１および検索結果一覧表示プログラム１２２による一連の文書検索処理を制御する。文書検索制御プログラム１１６ａは、まず文書検索の前準備として、磁気ディスク装置１０６に格納されている出現情報ファイル１０８と重みファイル１０９を主メモリ１１０に確保されたワークエリア１２８に読み込む。そして、文書検索処理では、図１１のＰＡＤ図に示すように、まずステップ１１００で、検索条件解析プログラム１１７を起動し、キーボード１０１から入力された検索条件を解析する。ここで、入力された検索条件には文章または文書が指定されていると、ステップ１１０１で判断された場合には、ステップ１１０２で検索文字列抽出プログラム１１８を用いて、検索条件として指定された文章または文書から、予め定められた文字列を抽出する。また、入力された検索条件には複数の単語の列が指定されていると、ステップ１１０１で判断された場合には、ステップ１１０３で検索条件から単語の列を抽出する。以上の処理内容は第一の実施例と同様である。次にステップ１１０４で、検索文字列編集プログラム９００を起動し、検索条件から抽出した文字列を表示する。そして、表示した文字列に対して、ユーザに検索に用いる文字列の追加、削除を行わせる。さらにステップ１１０５で、表示形式変更文字列選択プログラム９０１を起動し、編集結果の文字列から文書表示時に表示形式を変更する文字列をユーザに選択させ、その内容をワークエリア１２８に記憶する。次にステップ１１０６で、出現情報および重み取得プログラム１１９を起動し、編集結果の文字列の出現情報および重みを、ワークエリア１２８に読み込んだ出現情報ファイル１０８と重みファイル１０９から取得する。そしてステップ１１０７で、類似度算出プログラム１２１を起動し、ステップ１１０６で取得した文字列の出現情報と重みを用いて、予め定められた算出方法で検索条件とテキストデータ間の類似度を算出する。最後にステップ１１０８で、検索結果一覧表示プログラム１２２を起動し、ステップ１１０７で算出した類似度の降順にテキストデータを整列し、検索結果一覧として表示する。ステップ１１０６からステップ１１０８の処理内容は第一の実施例と同様である。以上で文書検索処理は終了する。

【００４３】文書を表示する際には、キーボード１０１からの文書表示指示により、システム制御プログラム１１１が文書表示制御プログラム１２３ａを起動し、文書表示制御プログラム１２３ａが表示形式変更文字列取得プログラム１０００、表示形式変更プログラム１２６および文書表示プログラム１２７による一連の文書表示処理を制御する。文書表示処理の処理内容を図１２のＰＡＤ図に示す。文書表示制御プログラム１２３ａは、図１２に示すように、まずステップ１２００で、表示形式変更文字列取得プログラム１０００を起動し、文書検索制御プログラム１１６ａによる文書検索処理で記憶した表示形式を変更する文字列をワークエリア１２８から取得する。次にステップ１２０１で、表示形式変更プログラム１２６を起動し、表示対象として指定された文書（以下、表示文書と呼ぶ）の中で、ステップ１２００で取得した文字列が含まれる部分の表示形式を変更する。この表示形式の変更方法は従来技術２と同様である。最後にステップ１２０２で、文書表示プログラム１２７を起動し、ステップ１２０１で表示形式を変更した表示文書を表示して文書表示処理を終了する。

【００４４】以上が本実施例における処理内容の概要である。

【００４５】以下、図１１に示した文書検索制御プログラム１１６ａによる文書検索処理、図１２に示した文書表示制御プログラム１２３ａによる文書表示処理の処理内容について、具体例を用いて詳細に説明する。

【００４６】文書検索制御プログラム１１６ａによる文書検索処理の内容は図１１に示す通りである。以下、具体的に説明する。まずステップ１１００で、検索条件解析プログラム１１７を起動し、キーボード１０１から入力された検索条件を解析する。ここで、入力された検索条件には文章または文書が指定されていると、ステップ１１０１で判断された場合には、ステップ１１０２で検索文字列抽出プログラム１１８を用いて、検索条件として指定された文章または文書から、予め定められた文字

列を抽出する。また、入力された検索条件には複数の単語の列が指定されていると、ステップ１１０１で判断された場合には、ステップ１１０３で検索条件から単語の列を抽出する。以上の処理内容は第一の実施例と同様である。次にステップ１１０４で、検索文字列編集プログラム９００を起動し、検索条件から抽出した文字列（以下、検索文字列と呼ぶ）を表示する。そして、表示した検索文字列に対して、ユーザに検索に用いる文字列の追加、削除を行わせる。さらにステップ１１０５で、表示形式変更文字列選択プログラム９０１を起動し、編集結果の文字列から文書表示時に表示形式を変更する文字列（以下、表示文字列と呼ぶ）をユーザに選択させ、その内容をワークエリア１２８に記憶する。図１３にステップ１１０４およびステップ１１０５における検索文字列編集および表示文字列選択の画面例を示す。本図に示す画面には、検索文字列の一覧が表示される。ここで、ユーザは検索に用いる文字列を選択し、検索用と表示されたチェックボックスをオンにする。この結果、チェックボックスをオンに設定した文字列が検索に用いられ、それ以外の文字列は検索対象から排除される。また、表示された検索文字列以外の文字列を検索に用いる場合には、“文字列の追加”ボタンを押して文字列追加指示を入力することにより、ユーザが希望する文字列を追加する。表示文字列の選択は、本画面において、表示用と表示されたチェックボックスをオンにすることにより実現できる。ここでチェックボックスをオンに設定した文字列が、文書表示時に表示形式を変更して表示される。ここでいう表示形式とは、例えば色、サイズ、フォントやスタイル（太字や斜体）等である。そして、全ての設定が終了した時点で、ユーザは“検索実行”ボタンを押して、検索実行指示を入力する。その結果、表示用のチェックボックスがオンに設定された文字列をワークエリア１２８に記憶し、ステップ１１０６からステップ１１０８を実行する。ステップ１１０６では、出現情報および重み取得プログラム１１９を起動し、編集結果の文字列、すなわち図１３において検索用のチェックボックスがオンに設定された文字列の出現情報および重みを、ワークエリア１２８に読み込んだ出現情報ファイル１０８と重みファイル１０９から取得する。そしてステップ１１０７で、類似度算出プログラム１２１を起動し、ステップ１１０６で取得した文字列の出現情報と重みを用いて、予め定められた算出方法で検索条件とテキストデータ間の類似度を算出する。最後にステップ１１０８で、検索結果一覧表示プログラム１２２を起動し、ステップ１１０７で算出した類似度の降順にテキストデータを整列し、検索結果一覧として表示する。ステップ１１０６からステップ１１０８の処理内容は第一の実施例と同様である。以上で文書検索処理は終了する。

【００４７】文書表示制御プログラム１２３ａによる文書表示処理の内容は図１２に示す通りである。以下、具体的に説明する。まずステップ１２００で、表示形式変更文字列取得プログラム１０００を起動し、文書検索制御プログラム１１６ａによる文書検索処理で記憶した表示形式を変更する文字列をワークエリア１２８から取得する。図１３に示す検索文字列編集および表示文字列選択画面の例では、ユーザは表示用として“サッカー”、“W杯”、“会場”および“ワールドカップ”のチェックボックスをオンに設定したので、ワークエリア１２８からこれらの文字列が取得される。次にステップ１２０１で、表示形式変更プログラム１２６を起動し、表示対象として指定された文書（以下、表示文書と呼ぶ）の中で、ステップ１２００で取得した文字列が含まれる部分の表示形式を変更する。この表示形式の変更方法は従来技術２と同様である。最後にステップ１２０２で、文書表示プログラム１２７を起動し、ステップ１２０１で表示形式を変更した表示文書を表示する。図１４に文書番号“１２３”、文書番号“００３”の文書表示例を示す。本図に示す例では、ステップ１２００で取得した文字列“サッカー”、“W杯”、“会場”および“ワールドカップ”が含まれる部分のサイズが大きく、斜体、強調が施されて表示されている。以上で、文書表示処理を終了する。

【００４８】以上説明したように、本実施例では、検索条件として指定された文章あるいは文書から抽出した検索用の文字列を編集する際に、文書表示時に表示形式を変更する文字列をユーザに選択させ、選択された文字列が含まれる部分の表示形式のみを変更している。文書や長い文章を指定して検索を行い、その結果として得られた文書を表示する際に、検索に用いた文字列全ての表示形式を変更すると、図３に示すように変更箇所が多くなり、かえって重要な部分が見つけにくくなるという問題があるが、本実施例に示す方法を用いることにより、ユーザが重要視している文字列のみに限定し、表示形式を変更することができる。

【００４９】このことにより、ユーザは文書中の重要箇所を瞬時に認識し、所望の文書か否かを高速に判別することが可能となる。その結果、検索結果文書を閲覧する際のユーザインターフェースを向上することができる。

【００５０】本実施例では、ユーザが選択した文字列の表示形式を変更する場合の例について説明したが、表示形式を変えるだけではなく、ユーザが選択した文字列に関する情報、例えば出現頻度等を一覧として表示することも上記と同様の処理で実現することが可能である。

【００５１】また本実施例では、ユーザに表示形式を変更する文字列を選択させる場合の例について説明したが、検索文字列を編集する際にユーザが追加した文字列の表示形式を変えることも上記と同様の処理で実現可能である。追加された文字列は、ユーザが重要視している文字列であるため、文書表示時にこの文字列の表示形式を変更することにより、文書中の重要箇所を瞬時に認識

することができる。

【００５２】また、指定された検索条件が、以前の検索結果一覧から選択された検索結果文書である場合に、その文書を検索するのに用いた検索条件中の文字列の表示形式を変えることも上記と同様の処理で実現可能である。例えば、単語を指定して検索を行い、その結果得られた文書を用いてさらに検索を行う場合では、最初に指定した単語は重要な単語である。文書表示時にこの単語の表示形式を変更することにより、文書中の重要箇所を瞬時に認識することができる。

【００５３】以下、本発明の第三の実施例について説明する。

【００５４】本実施例は、文書表示時に、その文書の得点算出に大きく寄与した文字列の表示形式を変更する（以下、ハイライトと呼ぶ）方法である。本方式を用いることにより、表示文書の得点がどのような文字列によって算出されたものであるかをユーザは瞬時に認識できるので、所望の文書か否かを高速に判別することが可能となる。

【００５５】本実施例は基本的に第一の実施例（図１）と同様の構成をとるが、その中の文書表示制御プログラム１２３が制御するプログラムの構成が異なる。文書表示制御プログラム１２３ｂが制御するプログラムの構成を図１５に示す。文書表示制御プログラム１２３ｂはキーボード１０１からの文書表示指示により、システム制御プログラム１１１によって起動され、出現情報取得プログラム１５００、文字列毎類似度算出プログラム１５０１、表示形式変更文字列抽出プログラム１２５、表示形式変更プログラム１２６および文書表示プログラム１２７の制御を行う。

【００５６】以下、第一の実施例と異なる文書表示制御プログラム１２３ｂによる文書表示処理の処理内容について説明する。

【００５７】文書を表示する際には、キーボード１０１からの文書表示指示により、システム制御プログラム１１１が文書表示制御プログラム１２３ｂを起動し、文書表示制御プログラム１２３ｂが出現情報取得プログラム１５００、文字列毎類似度算出プログラム１５０１、表示形式変更文字列抽出プログラム１２５、表示形式変更プログラム１２６および文書表示プログラム１２７による一連の文書表示処理を制御する。文書表示処理の処理内容を図１６のＰＡＤ図に示す。文書表示制御プログラム１２３ｂは、図１６に示すように、まずステップ１６００で、出現情報取得プログラム１５００を起動し、文書検索制御プログラム１１６による文書検索処理でワークエリア１２８に記憶した文字列とその重みを取得する。そして、表示対象として指定された文書（以下、表示文書と呼ぶ）を走査して、取得した文字列の表示文書における出現情報を取得する。この出現情報は文書登録制御プログラム１１２による文書登録処理で抽出される出現情報と同じものである。従来技術１の場合には、文書のベクトルを作成する際に必要となる文字列の出現回数を抽出する（表示文書１件に対する処理のみを行うので、出現情報として文書番号は不要）。次にステップ１６０１で、文字列毎類似度算出プログラム１５０１を起動し、ステップ１６００で取得した出現情報と重みを用いて、表示文書の類似度への文字列毎の寄与率を算出する。そして、この寄与率の降順に文字列を整列する。表示文書の類似度は文書検索制御プログラム１１６による文書検索処理で算出される、検索条件の内容と類似する度合いを表した数値である。一般的には文字列毎に出現情報や重みを用いて所定の方法で算出した値の総和を類似度とするため、この文字列毎に算出した値の類似度に対する割合を寄与率とすることができる。次にステップ１６０２で、表示形式変更文字列抽出プログラム１２５を起動し、ステップ１６０１で整列した文字列の上位m個（mは予め定められた１以上の整数）を抽出する。このmの値はシステムで自動的に適切な値を設定しても良いし、ユーザに予め設定させておいても良い。また、文書表示毎に対話的にユーザに設定させ、適切な値を調整してもかまわない。さらに寄与率のしきい値を決め、しきい値以上の寄与率の文字列を抽出しても良い。次にステップ１６０３で、表示形式変更プログラム１２６を起動し、表示文書の中で、ステップ１６０２で抽出した文字列が含まれる部分の表示形式を変更する。この表示形式の変更方法は従来技術２と同様である。最後にステップ１６０４で、文書表示プログラム１２７を起動し、ステップ１６０３で表示形式を変更した表示文書を表示して文書表示処理を終了する。

【００５８】以上が本実施例における処理内容の概要である。

【００５９】以下、図１６に示した文書表示制御プログラム１２３ｂによる文書表示処理の処理内容について、具体例を用いて詳細に説明する。まずステップ１６００で、出現情報取得プログラム１５００を起動し、文書検索制御プログラム１１６による文書検索処理でワークエリア１２８に記憶した文字列とその重みを取得する。そして、表示文書を走査して、取得した文字列の表示文書における出現情報を取得する。この出現情報は文書登録制御プログラム１１２による文書登録処理で抽出される出現情報と同じものである。従来技術１の場合には、文書のベクトルを作成する際に必要となる文字列の出現回数を抽出する（表示文書１件に対する処理のみを行うので、出現情報として文書番号は不要）。図１７に本処理の処理例を示す。検索に用いられた文字列“W杯”、“サッカー”、“会場”、“来月”、“決定”、…とその重みをワークエリア１２８から取得し、これらの文字列で表示文書を走査することにより出現情報を取得する。本図に示す例では、出現情報として文書における出現回数を用いている。次にステップ１６０１で、文字列

毎類似度算出プログラム１５０１を起動し、ステップ１６００で取得した出現情報と重みを用いて、表示文書の類似度への文字列毎の寄与率を算出する。そして、この寄与率の降順に文字列を整列する。表示文書の類似度は文書検索制御プログラム１１６による文書検索処理において算出される、検索条件の内容と類似する度合いを表した数値である。一般的には文字列毎に出現情報や重みを用いて所定の方法で算出した値の総和を類似度とするため、この文字列毎に算出した値の類似度に対する割合を寄与率とすることができる。図１７の例では、“W杯”、“サッカー”、“会場”、“来月”、“決定”、…の重みと表示文書における出現回数から、表示文書の類似度への文字列毎の寄与率を算出する。そしてこの寄与率の降順に文字列を整列することにより、“サッカー”、“W杯”、“会場”、“開催”、“決定”、…が得られる。次にステップ１６０２で、表示形式変更文字列抽出プログラム１２５を起動し、ステップ１６０１で整列した文字列の上位m個（mは予め定められた１以上の整数）を抽出する。このmの値はシステムで自動的に適切な値を設定しても良いし、ユーザに予め設定させておいても良い。また、文書表示毎に対話的にユーザに設定させ、適切な値を調整してもかまわない。さらに寄与率のしきい値を決め、しきい値以上の寄与率の文字列を抽出しても良い。図１８に本処理の処理例を示す。本図に示す例では、上位３個、すなわちmの値を３としている。その結果、表示形式を変更する文字列として“サッカー”、“W杯”および“会場”が抽出される。そしてステップ１６０３で、表示形式変更プログラム１２６を起動し、表示文書の中で、ステップ１６０２で抽出した文字列が含まれる部分の表示形式を変更する。この表示形式の変更方法は従来技術２と同様である。最後にステップ１６０４で、文書表示プログラム１２７を起動し、ステップ１６０３で表示形式を変更した表示文書を表示する。図１８に示す文書１２３の例では、表示形式を変更する文字列“サッカー”、“W杯”および“会場”が含まれる部分のサイズが大きく、斜体、強調が施されて表示されている。また本図には、文書００３を表示する場合の例も示している。文書００３が表示文書として指定された場合には、類似度への寄与率上位３個の文字列として“サッカー”、“準備”および“来月”が抽出され、これらの文字列が含まれる部分の表示形式を変更して文書が表示される。以上で、文書表示処理を終了する。

【００６０】以上説明したように、本実施例では、文書表示時に、その文書の得点算出に大きく寄与した文字列を抽出し、抽出した文字列が含まれる部分の表示形式のみを変更している。文書や長い文章を指定して検索を行い、その結果として得られた文書を表示する際に、検索に用いた文字列全ての表示形式を変更すると、図３に示すように変更箇所が多くなり、かえって重要な部分が見つけにくくなるという問題がある。しかし、本実施例に示す方法を用いることにより、表示文書の得点がどのような文字列によって算出されたものであるかをユーザは瞬時に認識できるので、所望の文書か否かを高速に判別することが可能となる。その結果、検索結果文書を閲覧する際のユーザインターフェースを向上することができる。

【００６１】本実施例では、文書の得点算出に大きく寄与した文字列の表示形式を変更する場合の例について説明したが、表示形式を変えるだけではなく、得点算出に寄与した文字列の情報、例えば寄与率等を一覧として表示することも上記と同様の処理で実現可能である。所望の文書ではなかった文書の得点算出に寄与した文字列を検索用の文字列から削除することにより、この文書の得点を小さくし、所望の文書の得点を相対的に大きくすることにより、高速に所望の文書を入手することができる。

【００６２】以上の実施例によれば、検索に用いられた文字列の数が大量となる場合でも、検索条件の内容と類似する可能性を示す指標に対して影響する文字列を選定し、それに関する情報のみを表示することができるため、ユーザは文書の重要箇所を瞬時に認識し、所望とする文書か否かを高速に判別することが可能となる。この結果、文書や長い文章を指定して検索を行い、その結果として得られた文書を表示する場合でも、所望の文書か否かの判別が容易な文書表示インターフェースを持つ文書検索システムを実現することができる。

【００６３】

【発明の効果】本発明によれば、所望の文書か否かの判別が容易な文書検索方法およびシステムを実現することができる。

【図面の簡単な説明】

【図１】本発明の第一の実施例の構成を示す図

【図２】従来技術１の処理内容を示す図

【図３】従来技術２の問題点の説明図

【図４】本発明の文書表示処理の内容を示す図

【図５】文書登録制御プログラム１１２の処理内容を示すPAD図

【図６】文書検索制御プログラム１１６の処理内容を示すPAD図

【図７】文書表示制御プログラム１２３の処理内容を示すPAD図

【図８】出現情報ファイル１０８と重みファイル１０９の作成例を示す図

【図９】本発明の第二の実施例における文書検索制御プログラム１１６ａの制御下のプログラムの構成を示す図

【図１０】本発明の第二の実施例における文書表示制御プログラム１２３ａの制御下のプログラムの構成を示す図

【図１１】文書検索制御プログラム１１６ａの処理内容

を示すPAD図
【図１２】文書表示制御プログラム１２３ａの処理内容を示すPAD図
【図１３】検索文字列編集および表示文字列選択画面例を示す図
【図１４】本発明の第二の実施例の文書表示処理の内容を示す図
【図１５】本発明の第三の実施例における文書表示制御プログラム１２３ｂの制御下のプログラムの構成を示す図
【図１６】文書表示制御プログラム１２３ｂの処理内容を示すPAD図
【図１７】本発明の第三の実施例の出現情報取得処理、文字列毎類似度算出処理の内容を示す図
【図１８】本発明の第三の実施例の表示形式変更文字列抽出処理、表示形式変更処理、文書表示処理の内容を示す図
【符号の説明】
１００・・・ディスプレイ、
１０１・・・キーボード、
１０２・・・ＣＰＵ、
１０３・・・バス、
１０４・・・フロッピディスクドライバ、
１０５・・・フロッピディスク、
１０６・・・磁気ディスク装置、
１０７・・・テキスト、
１０８・・・出現情報ファイル、
１０９・・・重みファイル、
＊１１０・・・主記憶装置、
１１１・・・システム制御プログラム、
１１２・・・文書登録制御プログラム、
１１３・・・テキスト登録プログラム、
１１４・・・出現情報ファイル作成プログラム、
１１５・・・重みファイル作成プログラム、
１１６・・・文書検索制御プログラム、
１１６ａ・・・文書検索制御プログラム、
１１７・・・検索条件解析プログラム、
１１８・・・検索文字列抽出プログラム、
１１９・・・出現情報および重み取得プログラム、
１２０・・・重み記憶プログラム、
１２１・・・類似度算出プログラム、
１２２・・・検索結果一覧表示プログラム、
１２３・・・文書表示制御プログラム、
１２３ａ・・・文書表示制御プログラム、
１２３ｂ・・・文書表示制御プログラム、
１２４・・・検索文字列整列プログラム、
１２５・・・表示形式変更文字列抽出プログラム、
１２６・・・表示形式変更プログラム、
１２７・・・文書表示プログラム、
１２８・・・ワークエリア、
９００・・・検索文字列編集プログラム、
９０１・・・表示形式変更文字列選択プログラム、
１０００・・・表示形式変更文字列取得プログラム、
１５００・・・出現情報取得プログラム、
１５０１・・・文字列毎類似度算出プログラム

＊

【図１】

図１

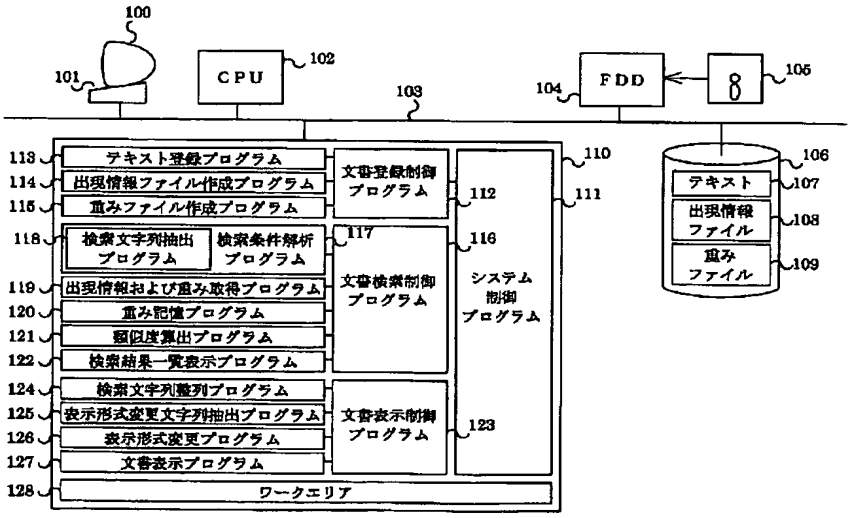

【図２】

図２

データベース中に存在する単語
(factors, information, help, human, operation, retrieval, systems)

検索条件：human factors in information retrieval systems

(factors, information, help, human, operation, retrieval, systems)
Q0= (1 , 1 , 0 , 1 , 0 , 1 , 1)

文書１：factors, information, human, retrieval を含む
V1= (1, 1, 0, 1, 0, 1, 0)
文書２：factors, help, human, systems を含む
V2= (1, 0, 1, 1, 0, 0, 1)
文書３：factors, operation, systems を含む
V3= (1, 0, 0, 0, 1, 0, 1)

単純なランキング	重みを用いたランキング
Q0=(1,1,0,1,0,1,1)	Q0=(1,1,0,1,0,1,1)
V1=(1,1,0,1,0,1,0)	V1=(2,3,0,5,0,3,0)
V1･Q0=(1,1,0,1,0,1,0)=4	V1･Q0=(2,3,0,5,0,3,0)=13
Q0=(1,1,0,1,0,1,1)	Q0=(1,1,0,1,0,1,1)
V2=(1,0,1,1,0,0,1)	V2=(2,0,4,5,0,0,1)
V2･Q0=(1,0,0,1,0,0,1)=3	V2･Q0=(2,0,0,5,0,0,1)=8
Q0=(1,1,0,1,0,1,1)	Q0=(1,1,0,1,0,1,1)
V3=(1,0,0,0,1,0,1)	V3=(2,0,0,0,2,0,1)
V3･Q0=(1,0,0,0,0,0,1)=2	V3･Q0=(2,0,0,0,0,0,1)=3

【図３】

図３

検索条件

サッカーW杯試合会場、来月決定、選定の権限は協会に。
日韓共催の二〇〇二年サッカーワールドカップ開催準備委員会は二十九日、開催地の候補である十五自治体の最高責任者らを集めて知事・市長会議を開いた。国際サッカー連盟（ＦＩＦＡ）が国内会場数を…

↓ 単語抽出

検索用単語

サッカー、W杯、試合、会場、来月、決定、選定、権限、協会、日、韓、共催、ワールドカップ、開催、準備、委員会、地、候補、…

↓ 検索

検索結果一覧

文書１２３	１００点
文書００３	９５点
文書０１２	７０点
文書０８９	６０点
：	

↓ 文書表示

文書１２３

*サッカーW杯会場*絞り込み、*来月決定*。
二〇〇二年*開催*の*サッカーワールドカップ*（*W杯*）の*開催準備委員会*は、*試合*を行う*国内会場数*を六～十ヵ所以内とする*国際サッカー連盟*（*ＦＩＦＡ*）案を*候補地*の*自治体*に連絡した。*日韓共催*のため…

文書００３

山形県、ＪＦＬ加盟の*サッカーチーム開設準備*。
山形県*サッカー委員会*は、ＪＦＬ加盟の*サッカー*チームの設立を*決定*し、*準備*室を*来月*開設する。同*準備*室を窓口として、*サッカー*チームの設立へ向けた出資者の募集や*試合会場*の*選定*などの*準備*をする。*会場*の*候補*として、…

【図４】

図４

文字列	重み
W杯	80
サッカー	80
会場	50
来月	20
決定	50
：	：

整列

文字列	重み
W杯	80
サッカー	80
ワールドカップ	70
ＦＩＦＡ	60
会場	50
：	：

上位ｍ個(m=4)抽出

文字列	重み
W杯	80
サッカー	80
ワールドカップ	70
ＦＩＦＡ	60

文書表示

文書１２３

*サッカーW杯*会場絞り込み、来月決定。
二〇〇二年開催の*サッカーワールドカップ*（*W杯*）の開催準備委員会は、試合を行う国内会場数を六～十ヵ所以内とする国際*サッカー*連盟（*ＦＩＦＡ*）案を候補地の自治体に連絡した。日韓共催のため…

文書００３

山形県、ＪＦＬ加盟の*サッカー*チーム開設準備。
山形県*サッカー*委員会は、ＪＦＬ加盟の*サッカー*チームの設立を決定し、準備室を来月開設する。同準備室を窓口として、*サッカー*チームの設立へ向けた出資者の募集や試合会場の選定などの準備をする。会場の候補として、…

【図５】

図５

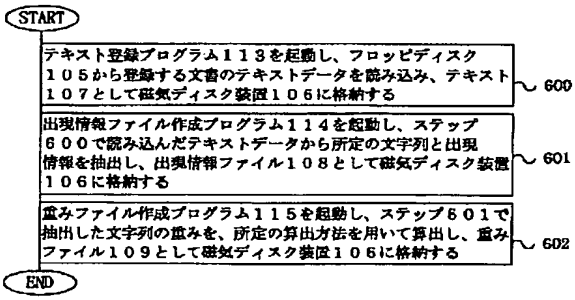

【図９】

図９

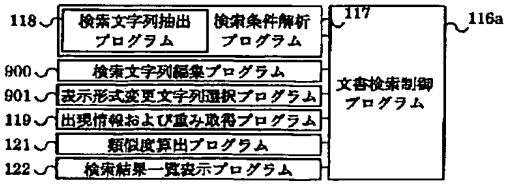

【図６】

図６

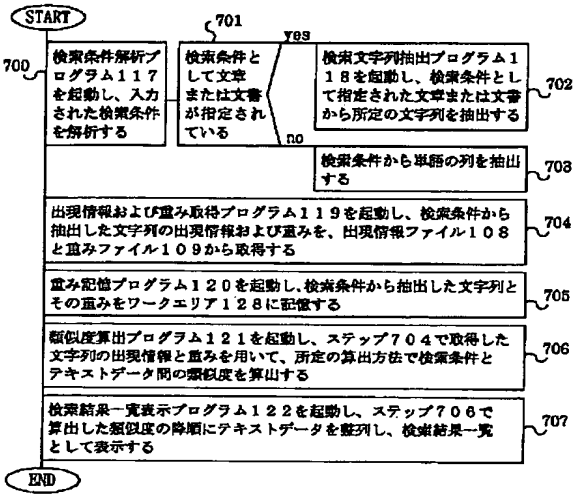

【図７】

図７

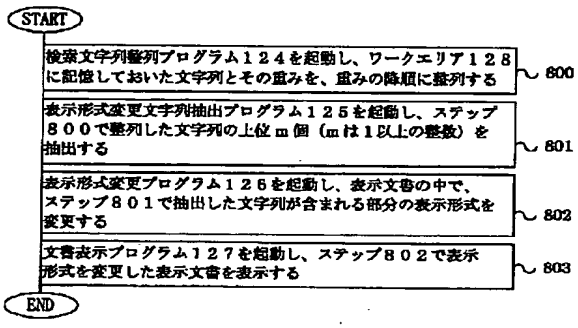

【図８】

図８

登録対象文書

文書１	W杯サッカー会場数、来月に決定―サッカー連会長見解。W杯…
文書２	銀行支店の開設が自由化へ、来月正式に決定。…
文書３	総合防災訓練、御殿場会場にて来月実施。…

出現情報格納　　重み格納

文字列	文書番号	出現回数
W杯	1	2
サッカー	1	3
会場	1	1
	3	2
来月	1	1
	2	1
	3	2
決定	1	2
	2	1
:	:	:

108 出現情報ファイル

文字列	重み
W杯	80
サッカー	80
会場	60
来月	20
決定	50
:	:

109 重みファイル

【図１０】

図１０

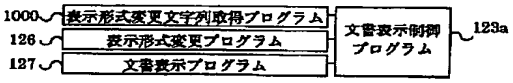

【図１１】

図１１

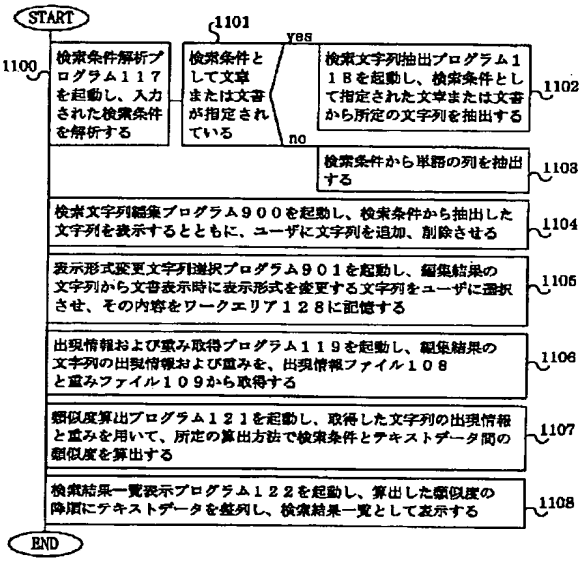

【図１２】

図１２

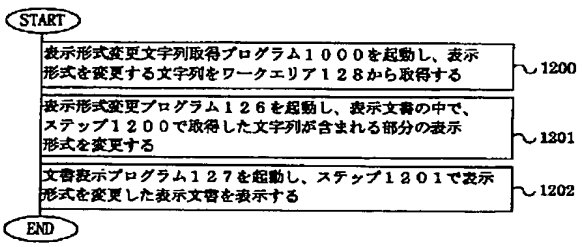

【図１５】

図１６

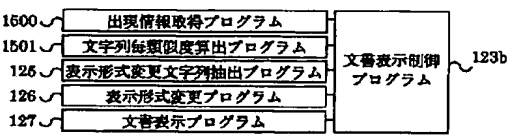

【図１３】

図１３

検索文字列編集および表示文字列選択画面

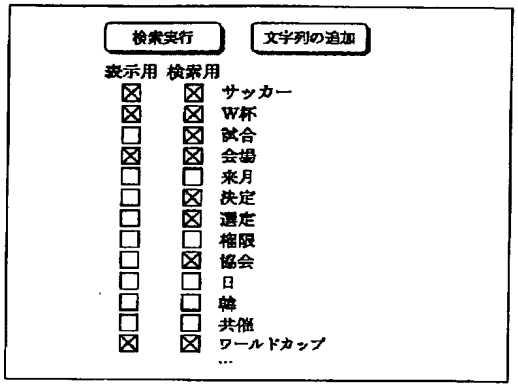

【図１４】

図１４

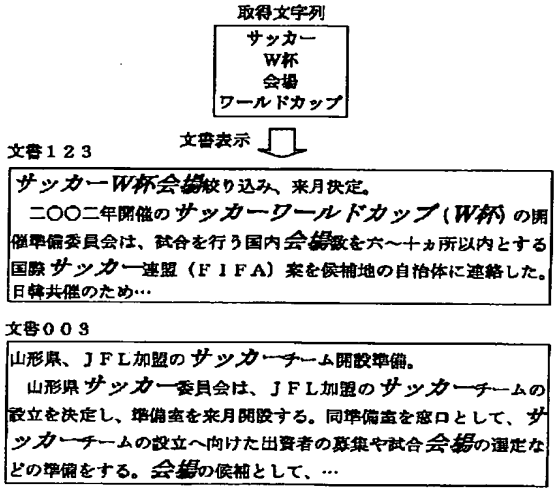

【図１６】

図１６

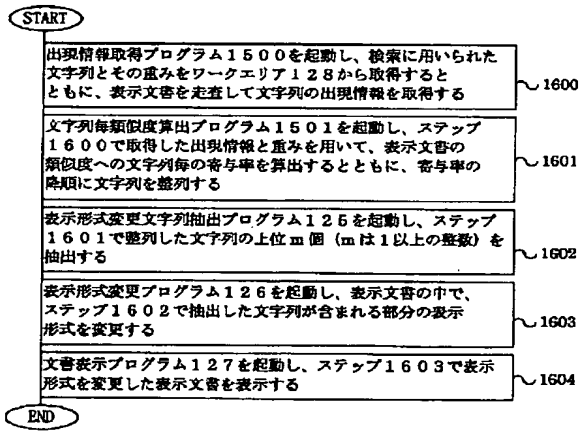

【図１７】

図１７

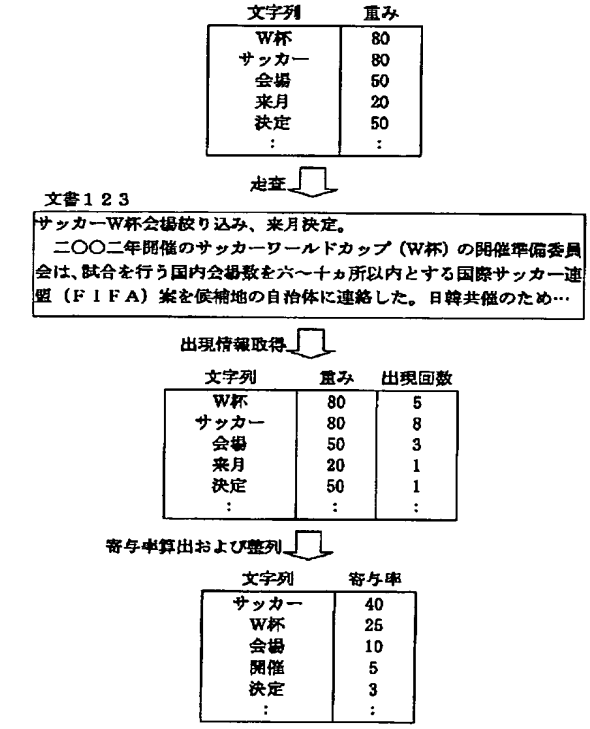

【図１８】

図１８

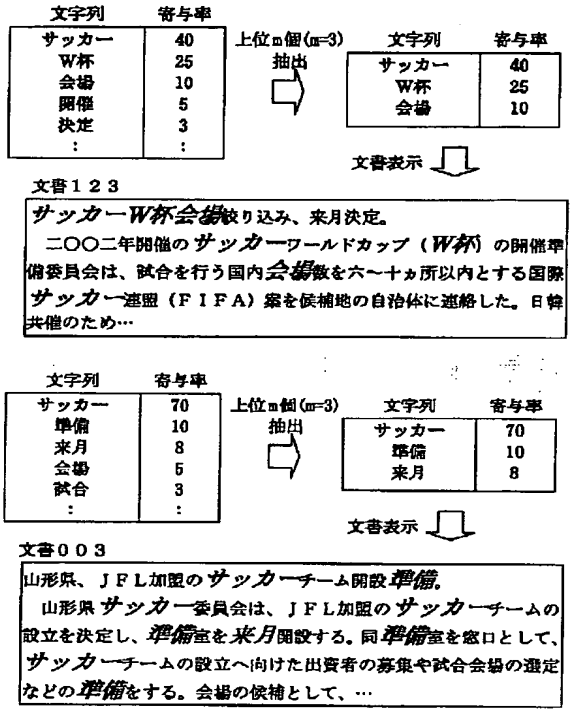

フロントページの続き

(72)発明者　松林　忠孝
神奈川県川崎市幸区鹿島田890番地　株式会社日立製作所ビジネスソリューション開発本部内
(72)発明者　山口　明彦
神奈川県川崎市幸区鹿島田890番地　株式会社日立製作所ビジネスソリューション開発本部内
(72)発明者　稲場　靖彦
神奈川県川崎市幸区鹿島田890番地　株式会社日立製作所ビジネスソリューション開発本部内
(72)発明者　後地　陽介
神奈川県横浜市戸塚区戸塚町5030番地　株式会社日立製作所ソフトウェア事業部内
Ｆターム(参考)　5B075 ND03 PQ02 PQ22 PQ36 PR04 PR06 QM08 UU06